

■ WHITEPAPER

Future Challenges in Logistics and Supply Chain Management

KÜNSTLICHE INTELLIGENZ IN DER LOGISTIK

■ WHITEPAPER

KÜNSTLICHE INTELLIGENZ IN DER LOGISTIK

Anbieter von kommerziellen Lösungen und Forschungseinrichtungen versprechen, dass mit Künstlicher Intelligenz (KI) – insbesondere dem Maschinellen Lernen (ML) – in der Logistik eine Vielzahl von Aufgaben wirtschaftlicher und ressourcenschonender durchgeführt werden können. In diesem Whitepaper werden daher die Grundlagen der KI sowie aktuelle Entwicklungen und zukünftige Einsatzfelder für KI in der Logistik vorgestellt und in Hinblick auf die Anwendungsreife diskutiert.

FUTURE CHALLENGES IN LOGISTICS AND SUPPLY CHAIN MANAGEMENT

Die Schriftenreihe »Future Challenges in Logistics and Supply Chain Management« greift aktuelle Herausforderungen auf, beleuchtet Trends und fokussiert neuartige Technologien und Geschäftsmodelle.

Die verschiedenen Ausgaben der Schriftenreihe zeichnen das Zukunftsbild einer innovativen Branche, das von Forschung und Praxis gestaltet und gelebt wird.

Autoren

Anike Murrenhoff, Fraunhofer IML
Martin Friedrich, Fraunhofer IML
Dr. Markus Witthaut, Fraunhofer IML

Herausgeber

Prof. Dr. Dr. h. c. Michael ten Hompel
Prof. Dr. Michael Henke
Prof. Dr.-Ing. Uwe Clausen

Internet

Das Whitepaper steht Ihnen auch im Internet unter www.innovationslabor-logistik.de zur Verfügung.

Kontakt

Fraunhofer-Institut für Materialfluss
und Logistik IML

Joseph-von-Fraunhofer-Str. 2–4
44227 Dortmund

schriftenreihe@iml.fraunhofer.de

DOI

10.24406/IML-N-462112

■ WHITEPAPER

INHALT

Bedeutung von Künstlicher Intelligenz für die Logistik	1
Hintergründe der Künstlichen Intelligenz	3
Definition des Begriffs Künstliche Intelligenz	3
Historie der Künstlichen Intelligenz.	4
ML-Software im Vergleich zu herkömmlicher Software	4
Ansätze des Maschinellen Lernens	5
Algorithmen für Maschinelles Lernen	8
Anwendungsbeispiele für Künstliche Intelligenz in der Logistik.	9
Klassifikationsdimension nach Logistikaufgabenbereich.	9
Klassifikationsdimension nach Kognitionsaufgabe	10
Anwendungsmodell des Maschinellen Lernens in der Logistik	10
ML für Erkennungsaufgaben	12
Beispiele für ML für Analyseaufgaben in der Logistik	13
Beispiele für ML für Planungs- und Entscheidungsaufgaben in der Logistik .	15
Beispiele für ML für Ausführungsaufgaben in der Logistik	17
Projekte mit maschinellem Lernen – Wie starten?.	18
Schlussbetrachtung.	19
Qualifizierungsbedarfe	19
KI in der Logistik: Chancen und Ausblick.	20
Literaturverzeichnis	21

Bedeutung von Künstlicher Intelligenz für die Logistik

Künstliche Intelligenz (KI) ist in den letzten Jahren zu einem der Topthemen in einer Vielzahl an Foren, Zeitungsartikeln, Expertenrunden und in der Wirtschaft geworden. Sie wird von der Deutschen Bundesregierung als die wesentliche Schlüsseltechnologie der wirtschaftlichen Leistungsfähigkeit des Landes gesehen und gefördert [1]. Auch in der Logistikbranche steigt die Bedeutung dieser Technologie schnell: gut 70 % der Teilnehmer der Bitkom-Studie »Digitalisierung der Logistik« aus dem Jahr 2019 sind der Meinung, dass KI in 10 Jahren für die Logistik unverzichtbar ist (vgl. Abbildung 1). Dennoch zeigt die Studie auch, dass sich bisher nur knapp 15 % der Unternehmen mit KI beschäftigen oder dies planen.

2030: Künstliche Intelligenz wird für die Logistik unverzichtbar

Wie verbreitet werden die folgenden Szenarien in zehn Jahren sein?

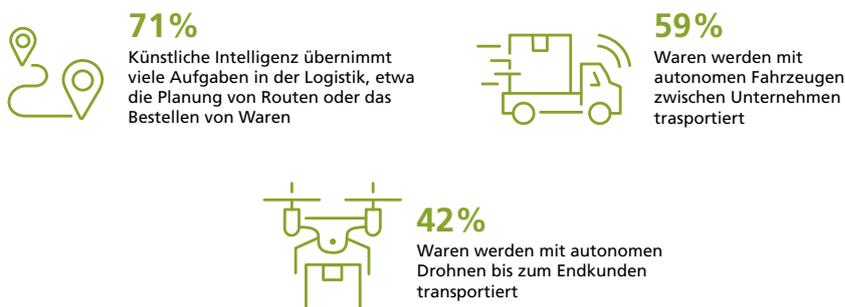


Abbildung 1
Einschätzung deutscher Unternehmen über den Stellenwert der KI für die Logistik [2]

Ein ähnliches Bild gibt eine Studie aus 2020 von Tata Consultancy und Bitkom. 47 % der befragten Unternehmen sehen KI als eine Schlüsseltechnologie für die Logistik an [21]. Bemerkenswert ist jedoch hierbei, dass nur 10 % der befragten Unternehmen KI bereits einsetzen und 17 % den Einsatz konkret geplant haben. Als Hauptthemnisse für eine schnelle Einführung von KI und ML werden hohe Investitionskosten, Anforderungen an die Datensicherheit, langer Entscheidungsprozess, Anforderungen an den Datenschutz, fehlende Anwendungsbeispiele, Komplexität des Themas sowie Mangel an Expertise genannt.

Die Relevanz, die KI in der Logistikbranche in Deutschland zugeschrieben wird, lässt sich vor allem durch die Charakteristika der Optimierungsprobleme in der Logistik sowie den hohen wirtschaftlichen und gesellschaftlichen Stellenwert der Logistik in Deutschland begründen: Laut ten Hompel ist die Logistik, wie die Geometrie, vollständig deterministisch und algorithmierbar [4]. Die einzelnen Prozessschritte der physischen Logistik – wie transportieren, umschlagen, ein- und auslagern, picken und (ver-)packen – sind leicht verständlich und vollständig beschrieben. Durch die

Kombination dieser Prozessschritte, beispielsweise die Zusammenfassung von einzelnen Sendungen zu Transporten oder der Transport mit einem Vor-, Haupt- und Nachlauf inklusive der zugehörigen Transportmodiwechsel, entstehen hochkomplexe Optimierungsprobleme.

Die Bewältigung dieser Optimierungsaufgaben mittels etablierter Verfahren aus dem Operations Research gestaltet sich in der Praxis schwierig. Diese Methoden setzen voraus, dass die wesentlichen Optimierungskriterien und Randbedingungen vollständig in einem expliziten mathematischen Optimierungsmodell abgebildet sind. Unter dem Begriff Advanced Planning wurde und wird z. B. seit Mitte der 1990er Jahre versucht, diese Methoden insbesondere in den Anwendungsfeldern Supply Chain Management, Produktionsplanung und -steuerung sowie Warehouse Management in Software umzusetzen. Beim Praxiseinsatz zeigt sich, dass die Leistungsfähigkeit und Flexibilität menschlicher Entscheider durch APS-Verfahren nicht erreicht werden [5]. An dieser Stelle können Verfahren der KI ihr Potenzial entfalten, denn sie sind in der Lage komplexe Zusammenhänge abzubilden und aus Erfahrungen zu lernen.

Der hohe Stellenwert, den Logistik in der deutschen Wirtschaft hat, verspricht einen großen Hebeleffekt für durch KI-Verfahren mögliche Optimierungsansätze. In 2019 war die Logistik nach der Automobilwirtschaft und dem Handel mit einem Umsatz von rund 279 Milliarden Euro der größte Wirtschaftsbereich in Deutschland und beschäftigte mehr als 3,2 Millionen Menschen [6]. Auch international ist die deutsche Logistikbranche anerkannt: die Weltbank hat Deutschland in 2018 zum dritten Mal in Folge zum Logistikweltmeister ernannt [7]. Dass der Einsatz von KI in dieser wirtschaftlich wichtigen Branche besonders große Effekte bietet zeigt auch eine Studie von McKinsey, in der das Gesamtpotenzial von Optimierungen und Effizienzsteigerungen durch den Einsatz von KI in der Produktion und im Supply Chain Management (SCM), zwei wichtigen Kerngebieten der Logistik, auf 1,2 bis 2,0 Billionen US-Dollar geschätzt wird [8].

Die Relevanz der KI in der Logistik ist also groß und entwickelt sich immer mehr zu einem Zukunftstreiber. In diesem Whitepaper werden Anwendungsbeispiele für KI in der Logistik vorgestellt und diskutiert. Zum besseren Verständnis der KI-Verfahren werden zunächst die Ursprünge und grundlegenden Ansätze der KI inklusive des Unterschieds zu bisherigen Methoden beschrieben.

Hintergründe der Künstlichen Intelligenz

DEFINITION DES BEGRIFFS KÜNSTLICHE INTELLIGENZ

In einem viel zitierten Artikel von 1950 schlug der britische Mathematiker und Computer-Wissenschaftler Alan Turing zur Definition des Begriffs Künstliche Intelligenz einen Test vor, den er als Imitation Game bezeichnete [9]: ein Computer wird als intelligent erachtet, wenn ein Mensch in der Interaktion mit diesem Computer nicht unterscheiden kann, ob er mit einer Maschine oder einem Menschen kommuniziert. Dieser Test wird als Turing-Test bezeichnet und dient als eine weit akzeptierte Definition für den Begriff Künstliche Intelligenz (KI) bzw. Artificial Intelligence (AI).

Beachtenswert in Turings Artikel von 1950 ist seine Prognose, dass zum Ende des zwanzigsten Jahrhunderts intelligente Maschinen einsatzfähig sein werden. Es hat etwas mehr Zeit benötigt, doch seit einigen Jahren wird unser alltägliches Leben mehr und mehr von intelligenten Programmen durchdrungen: Konsumenten unterhalten sich mit intelligenten Assistenten wie z. B. Alexa (Google), Siri (Apple) oder Cortana (Microsoft) in der gleichen Art, wie in der Kommunikation mit Menschen. Weiterhin prognostizierte Turing, dass nur lernende Maschinen wirklich intelligentes Verhalten entwickeln können. Bemerkenswert an dieser Einschätzung ist, dass die KI-Methoden ohne Maschinelles Lernen – als prominentes Beispiel seien hier die in den 1980er propagierten regelbasierten Expertensysteme genannt – bis heute keinen Durchbruch in der Praxis erzielen konnten. Maschinelles Lernen ist also von zentraler Bedeutung für die Künstliche Intelligenz.

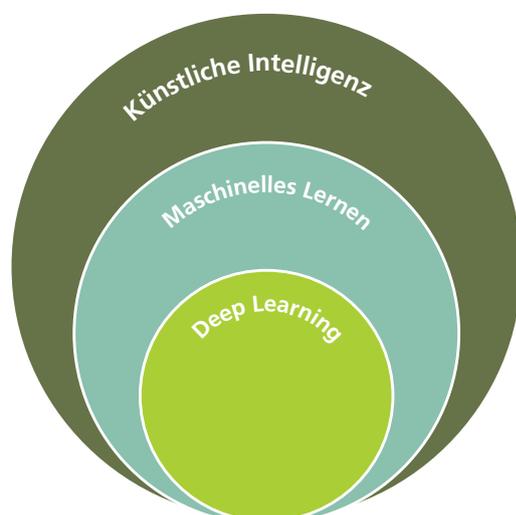
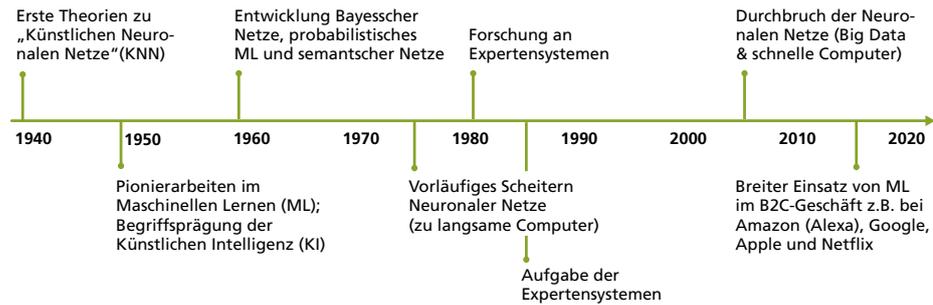


Abbildung 2
Maschinelles Lernen
als Teilgebiet der
Künstlichen Intelligenz [10]

HISTORIE DER KI

Seit den Anfängen der KI in den späten 1940er Jahren wurden in dieser Forschungsdisziplin unterschiedliche Ansätze für ML entwickelt und erprobt. In Abbildung 3 sind entsprechende Meilensteine dargestellt.

Abbildung 3
Meilensteine des
Machine Learnings
(basierend auf [11])



Aus Abbildung 3 wird ersichtlich, dass die theoretischen Methoden des ML schon seit Jahrzehnten entwickelt wurden. Aber erst durch die wachsenden Mengen und Varietäten der Daten, moderne Technologien der Industrie 4.0 und die stark gestiegenen Leistungen von Computern sowie die sinkenden Preise für Computer und Datenspeichersysteme kommt es zum Praxiseinsatz von ML-Verfahren.

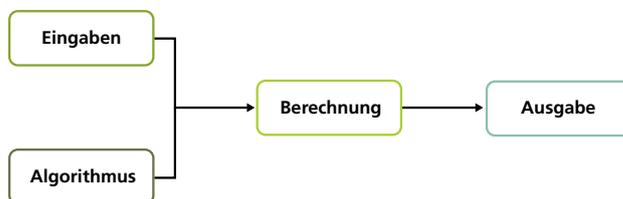
ML-SOFTWARE IM VERGLEICH ZU HERKÖMMLICHER SOFTWARE

Ursprünglich entstand das Forschungsgebiet ML aus dem Bereich Mustererkennung und der Theorie, dass Computer das Erfüllen von Aufgaben erlernen können, ohne explizit für diese Aufgaben programmiert zu werden. Im Laufe der Zeit wurde hierfür eine Vielzahl von modellbasierten Algorithmen entwickelt. Diese Programme unterscheiden sich grundsätzlich von herkömmlicher Software in der Anpassungsfähigkeit an sich ändernde Sachverhalte. Herkömmliche Software ist dadurch gekennzeichnet, dass der Algorithmus nach dem Programmieren nicht mehr geändert wird (vgl. Abbildung 4). Spätere Änderungen in den Anforderungen erfordern eine Anpassung der Software durch Softwareentwickler. Das Prinzip der ML-Programme hingegen ist ähnlich dem des menschlichen Lernens. Eine ML-Software besteht hierbei aus Eingaben, einem Modell und Ausgaben. Die Komponenten zur Erfassung der Eingaben bilden dabei die Sensorik und die Ausgaben zeigen an, wie das ML-System auf diese Eingaben reagiert. Diese Reaktion hängt vom internen Modell ab, welches mit unterschiedlichen mathematischen Verfahren die jeweiligen Ausgaben erzeugt. Auf Basis von Beispieldaten für Eingaben und Rückmeldungen in Bezug auf die erwarteten Ausgaben passt eine ML-Software sein Modell an.

Unter der Voraussetzung, dass Daten vorhanden, aus denen ein Zusammenhang erlernt werden kann, bietet der Einsatz von ML-Software in zwei Situationen Vorteile:

- Der Zusammenhang zwischen Eingaben und Ergebnis ändert sich im Laufe der Zeit, sodass sich auch das Modell anpassen muss.
- Der Zusammenhang zwischen Eingaben und Ergebnis ist so komplex, dass herkömmliche Algorithmen diesen nicht abbilden können oder dass die Performance dieser Algorithmen für die Anwendung nicht ausreichend ist.

Herkömmliche Software



Maschinelles Lernen

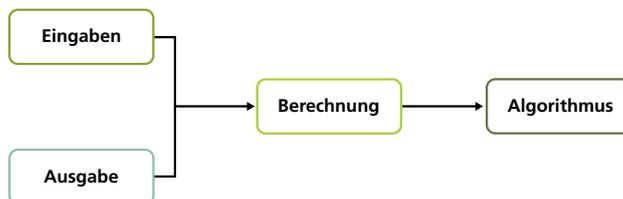


Abbildung 4
Unterschiede zwischen
herkömmlicher Software
und ML-Software

ANSÄTZE DES MASCHINELLEN LERNENS

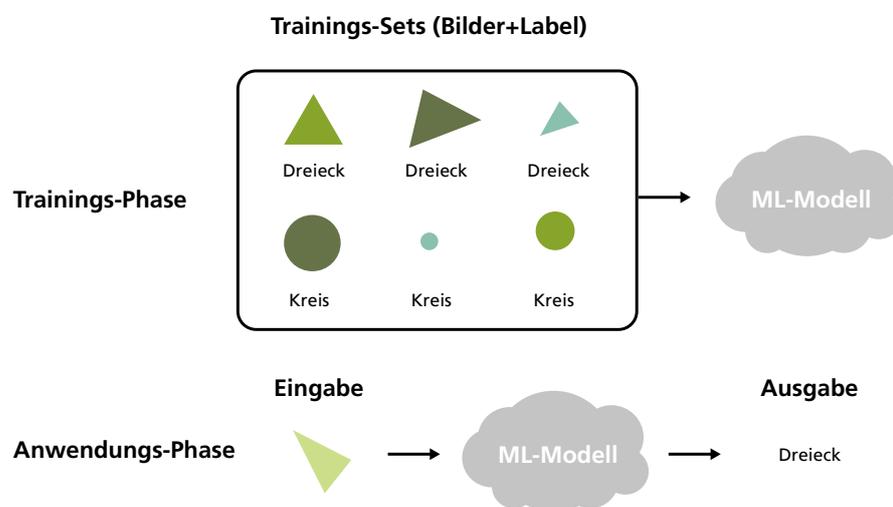
Die Definition von KI – ein Computer ist intelligent, wenn Menschen ihn als intelligent erachten – gibt nicht vor, mit welchen Softwaremethoden das Ziel der Nachahmung von menschlicher Intelligenz und menschlichem Lernen erreicht werden soll. Entsprechend ist es nicht überraschend, dass seit Anfang der 1950er Jahre eine Vielzahl unterschiedlicher Ansätze und Algorithmen für die KI entwickelt worden sind. In Hinblick auf das maschinelle Lernen werden dabei die ML-Verfahren grundsätzlich in drei Arten eingeteilt (vgl. z. B. [9]).

ÜBERWACHTES LERNEN

Beim überwachten Lernen gibt es eine sogenannte Grundwahrheit, d. h. bereits im Vorhinein ist für die Eingaben das jeweils richtige Ergebnis bekannt. Entsprechend kann das ML-Modell mit einem Trainingsdatensatz (Eingaben + erwartete

Ergebnisse) so lange trainiert werden, bis es das richtige Verhalten erlernt hat. Hierbei wird ein ML-Modell mit einer großen Anzahl an Paaren aus Daten und zugehörigen Labeln trainiert. Nach der Trainingsphase kann dann das ML-System auch Daten erfolgreich klassifizieren, die nicht im Trainings-Set enthalten sind. In Abbildung 5 ist dieser ML-Ansatz in vereinfachter, abstrakter Form für die Bilderkennung dargestellt. Grundsätzlich kann aber auch anderes Wissen – z. B. die Erkennung von gesprochener Sprache, die Klassifikation von Tätigkeiten aus Bewegungsbildern oder Klassifikation von Dokumenten auf Basis von Schlüsselwörtern – erlernt werden.

Abbildung 5
ML mit überwachtem
Lernen (Klassifikation)



Neben solchen Klassifizierungsaufgaben werden ML-Verfahren mit überwachtem Lernen auch für Regressionsaufgaben eingesetzt. Hierbei lernt das ML-System eine Funktion, d. h. basierend auf Eingabewerten soll auf einen Ausgabewert geschlossen werden. Beispielsweise kann ein ML-System den Zusammenhang zwischen Körpergewicht von Menschen in Bezug zu anderen Größen wie z. B. Körperhöhe, Bauchumfang und Angaben zum Geschlecht mittels Regression erlernen.

UNÜBERWACHTES LERNEN

Beim unüberwachten Lernen sucht das ML-Programm in den Eingabedaten nach Mustern. Im Gegensatz zum überwachten Lernen wird also kein Ziel vorgegeben, dass das ML-Programm erlernen soll. Hierbei kommen Methoden u. a. aus dem Data Mining und der multivariaten Statistik zum Einsatz. Ein oft zitiertes Praxisbeispiel ist die Erkennung, ob Kundinnen eines Supermarkts ein Kind erwarten oder nicht. Auf Basis des Einkaufsverhaltens der Kundinnen wird dies vom ML-System gelernt, um diesen Kundinnen dann später maßgeschneiderte Angebote – beispielsweise Babykleidung – zukommen zu lassen [12], [13].

Andere Formen des unüberwachten Lernens finden sich in der Bildverarbeitung, um in Fotos durch Segmentierung bestimmte Bildbereiche automatisch zu erkennen. In Abbildung 6 ist ein abstraktes Beispiel dargestellt, in welchem ein ML-Programm Bilder von unterschiedlich großen, verschiedenfarbigen Dreiecken, Kreisen und Rechtecken als Eingabe erhält und die entsprechenden Cluster bildet. Hierbei können auch bei gleichen Eingaben unterschiedliche Cluster gebildet werden. D. h., ein ML-Programm sortiert die Eingaben nach Größe, ein anderes nach Form und ein weiteres nach Farbe.

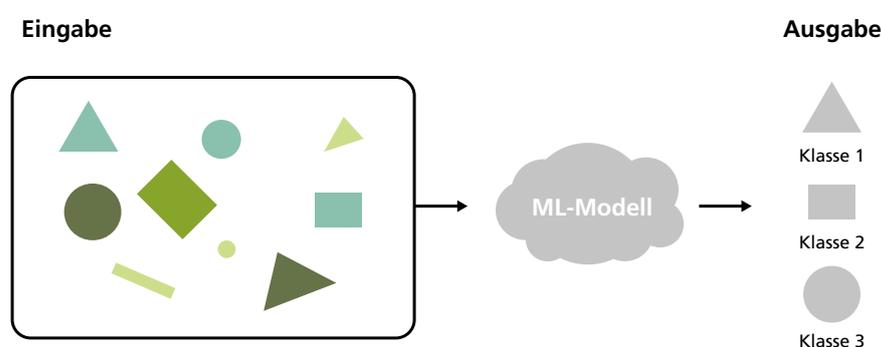
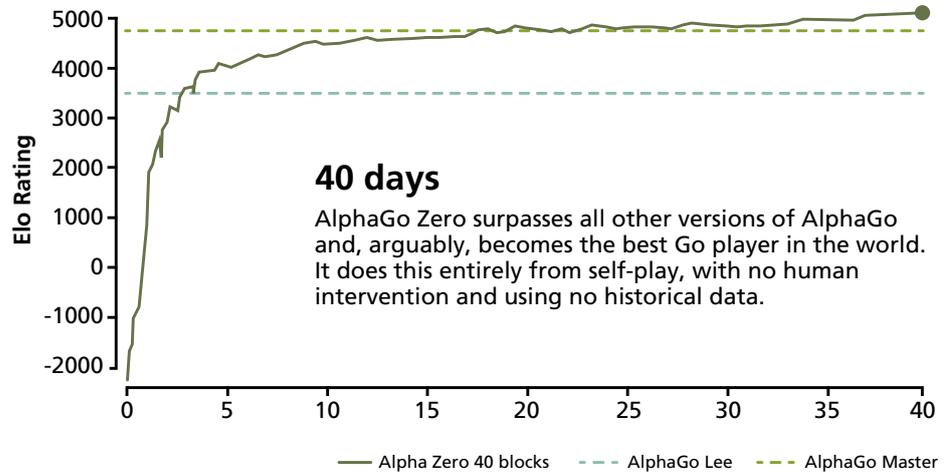


Abbildung 6
ML mit unüberwachtem ML

BESTÄRKENDES LERNEN

Bestärkendes Lernen bzw. verstärkendes Lernen – Übersetzung des englischen Fachbegriffs reinforcement learning – ist die dritte grundsätzliche Art und Weise des ML. Hierbei soll das ML-Programm ein Verhalten erlernen. Im Gegensatz zum überwachten Lernen gibt es kein Paar von Eingaben und „richtigen“ Ausgaben (erwarteten Ergebnissen). Das heißt, während des Lernens wird dem ML-Programm in einer bestimmten Situation nicht vorgezeigt, welche Aktion in dieser Situation die beste ist. Stattdessen wird jede Aktion des ML-Programms anhand einer zuvor definierten Funktion bewertet. Mit dieser Bewertung passt dann das ML-Programm sein Modell an, um so immer bessere Bewertungen zu erzielen. Ein bekanntes Beispiel ist AlphaGo Zero. Dieses ML-Programm hat in 40 Tagen das japanische Brettspiel Go und Schach so gut erlernt, dass es besser als der menschliche Weltmeister spielt [14]. In Abbildung 7 ist die Spielleistung von AlphaGo Zero beim GO-Spiel über die Trainingszeit dargestellt. Hierbei hat das Programm immer wieder gegen sich selbst gespielt und wurde nach und nach immer besser.

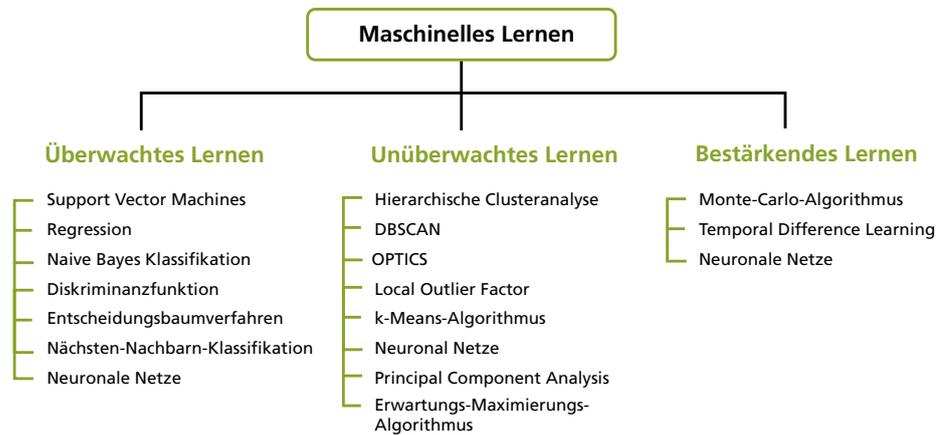
Abbildung 7
Lernfortschritt von
AlphaGo Zero mit bestär-
kendem Lernen [15]



ALGORITHMEN FÜR MASCHINELLES LERNEN

Es gibt eine große Zahl unterschiedlicher ML-Verfahren (vgl. Abbildung 8). Eine Beschreibung der Funktionsweise dieser einzelnen Ansätze kann bspw. in [16] gefunden werden.

Abbildung 8
Zuordnung gängiger
Verfahren zu den drei
ML-Ansätzen



Anwendungsbeispiele für Künstliche Intelligenz in der Logistik

Neben neuen Anwendungsbereichen, wie der Bilderkennung und -interpretation, werden ML und KI auch dazu genutzt, bisherige Prognose- und Optimierungsverfahren zu ersetzen und dadurch genauere Ergebnisse zu erzielen. In einer Studie von INFORM und Logistik heute sehen die Experten verschiedener logistischer Disziplinen die wichtigsten Anwendungsgebiete für ML in der Bedarfsprognose und Absatzplanung, der Transportoptimierung (bspw. durch autonome Transportsysteme) und der Produktionsoptimierung [17]. KI und ML bieten dabei die Möglichkeit, verschiedene Datenströme in einem Modell zusammenzuführen und dadurch Sachverhalte und Abhängigkeiten zu entdecken. Dadurch ergeben sich genauere Vorhersagen, die die Grundlage für die Planung bilden. Das McKinsey Global Institute schätzt, dass in den meisten Anwendungsfällen der Einsatz von KI in der Logistik und im SCM zu einer Steigerung der Ressourceneffizienz führt. Mit weniger Personalaufwand werden implizit in den Daten vorhandene Abhängigkeiten erkannt und somit bessere Entscheidungen getroffen [7].

Die Anwendungsbereiche von KI und ML in der Logistik werden im Folgenden näher betrachtet. Entsprechend der Bedeutung und der Einsatzfelder der Logistik ist der Anwendungsbereich sehr groß. Eine Systematisierung des Anwendungsbereichs ist also angebracht. Diese Anwendungssystematik ordnet die oben genannte Einteilung von INFORM und Logistik heute in eine stärker gegliederte Struktur, welche auf Forschungsarbeiten am Fraunhofer IML fußt. Diese Anwendungssystematik verfügt über zwei Klassifikationsdimensionen.

KLASSIFIKATIONSDIMENSION NACH LOGISTIKAUFGABENBEREICH

Die erste Anwendungsdimension entsteht aus der Aggregation eines am Fraunhofer IML entwickelten Aufgabenmodells für IT-Systeme in der Logistik [18]: Dazu werden drei Anwendungsbereiche Beschaffung & Einkauf, Produktion sowie Vertrieb & Distribution betrachtet. In jedem dieser Bereiche finden sich physische Tätigkeiten für Transport, Umschlag und Lagerung von Gütern und die zugehörigen Planungs- und Steuerungsaufgaben. Zusätzlich müssen neben Gütern auch Anlagen und Hilfsmittel betrachtet werden, bei denen die Aufgaben der Wartung und Instandhaltung eine wichtige Rolle spielen.

KLASSIFIKATIONSDIMENSION NACH KOGNITIONSAUFGABE

Die zweite Dimension zur Strukturierung der Anwendungsbeispiele für ML in der Logistik stammt aus einer abstrahierten Klassifikation von KI-Aufgaben. Mit KI strebt man an, das intelligente Verhalten von Menschen nachzubilden bzw. zu imitieren. Konkret geht es darum, kognitive Fähigkeiten des Menschen nachzubilden. Unter Kognition werden in der Psychologie Prozesse und Strukturen zur Aufnahme, Verarbeitung und Speicherung von Informationen verstanden [19]. Eine ähnliche Einteilung erfolgt in der aus sechs Klassen bestehenden Klassifikation für logistische Assistenzsysteme für die Entscheidungsunterstützung: Erzeugen und Aufbereiten (Filtern) von Informationen, Erzeugen von Alternativen, Bewerten von Alternativen, Auswählen von Alternativen, Überwachung/Monitoring der Entscheidungsausführung und Kontrollieren der Entscheidungsausführung [20]. Basierend auf diesen beiden Klassifikationsdimensionen erfolgt eine Betrachtung von vier Aufgaben von ML-Systemen:

- Erkennen
- Analysieren
- Planen und Entscheiden
- Ausführen

ANWENDUNGSMODELL DES MASCHINELLEN LERNENS IN DER LOGISTIK

Durch Kombination des Logistikaufgabenbereichs mit der Kognitionsaufgabe entsteht ein Anwendungsmodell des Maschinellen Lernens in der Logistik (vgl. Abbildung 9). Zweck dieses Modells ist es, Anwendern eine strukturierte Übersicht des Einsatzes von ML in der Logistik zu geben.

Bereich Aufgabe	Beschaffung & Einkauf	Produktion	Vertrieb & Distribution
Erkennung	Lokalisierung, Identifikation und Zählen von Objekten		
	Sprach-, Gesten- und Gesichtserkennung zur Mensch-Maschine-Kommunikation		
	Identifikation von Versorgungsrisiken	Condition Monitoring	Änderungen des Kundenverhaltens
Analyse	Lieferantenbewertung	Anlagenperformance	Kundenklassifikation
	Bedarfsprognose		
	Dokumentenanalyse zur Extraktion von Informationen (Bestellungen, Lieferscheine, Rechnungen...) aus semistrukturierten Daten		
Planen und Entscheiden	Lieferantenauswahl	Produktionsprogramm und Kapazitäten	Absatz
	Bestände (Materialien/Teile, WIP, Fertigprodukte)		
	Transportkapazitäten, Transportmodi, Sendungen, Routing	Fertigungsaufträge und Produktionsreihnfolge	Transportkapazitäten, Transportmodi, Sendungen, Routing
	Entladung, Lagerplatzvergabe und Einlagerung	Innerbetriebliche Transporte (Scheduling)	Picken, Packen, Verpacken und Beladen
Ausführen	Autonomes Fahren (öffentliche Straßen)	Automatisierung der Transports (innerbetrieblich)	Autonomes Fahren (öffentliche Straßen)
	Steuerung der Automatisierungstechnik in Wareneingang und Lagerung	Automatische Produktion	Steuerung der Automatisierungstechnik in Kommissionierung und Warenausgang

Abbildung 9
Dortmunder Anwendungsmodell des Maschinellen Lernens in der Logistik

In den einzelnen Feldern des Anwendungsmodells können grundsätzlich alle Ansätze und Algorithmen des Maschinellen Lernens eingesetzt werden. Die Frage, ob überwachtes, unüberwachtes oder bestärkendes Lernen zum Einsatz kommt, hängt von den Aufgaben im Detail ab. So kann z. B. die Analyse der Anlagenperformance mit Daten aus unterschiedlichen Quellen – z. B. Sensor-Daten der Anlagen, Produktstammdaten und QS-Daten der produzierten Produkte – mit allen drei ML-Ansätzen durchgeführt werden: Beim unüberwachten Lernen werden automatisch Muster in den Daten erkannt. Der Vorteil des sehr hohen Automatisierungsgrads wird dabei mit dem Risiko der Erkennung von Schein-Mustern erkaufte. Beispielsweise kann das ML-System erkennen, dass Produktionsprobleme einem bestimmten Artikel zugeordnet werden, welcher immer anfangs der Woche produziert wird. Die Probleme können jedoch vom Hochfahren der Produktionsanlagen stammen. Dieses Risiko kann mit überwachtem Lernen vermieden werden, indem die Trainingsdaten ausgewählt und die Lernperformance durch menschliche Trainer überwacht werden. Auch ist in diesem Anwendungsfall der Einsatz des bestärkenden Lernens denkbar. Hier wird in einer Trainingsphase jeder vom ML-System genannte Grund für einen Produktionsfehler durch eine externe Instanz – beispielsweise eine QS-Abteilung – bewertet. Im Folgenden werden Anwendungsbeispiele aus der Logistik anhand dieses Anwendungsmodelles vorgestellt.

ML FÜR ERKENNUNGSAUFGABEN

ERKENNUNG VON GEFAHRGUT LABELN

Die Erkennung von Gefahrgutlabeln auf Verpackungen ist eine wichtige Aufgabe bei der Handhabung von Packstücken. Hierbei ist zu beachten, dass es unterschiedliche Klassen von Gefahrgut gibt, beispielsweise Gifte, Gase oder entzündbare flüssige Stoffe und dass für jede dieser Klassen unterschiedliche Label mit unterschiedlichen Varianten verwendet werden (vgl. Abbildung 10). Für eine zuverlässige Gefahrgutklassifikation eines Packstücks muss ein System erkennen, ob dieses Packstück mit einem Gefahrgutlabel versehen ist und welche Art von Label verwendet wird. Es ist auch zu beachten, dass diese Label aus unterschiedlichen Perspektiven wahrgenommen werden können. Gleiches gilt für unterschiedliche räumliche Ausrichtungen.

Abbildung 10
Unterschiedliche Varianten für ein Gefahrgutlabel der Klasse 3 (brennbare Flüssigkeiten)



Mit einem ML-System kann die Erkennung von Gefahrgut so automatisiert werden, dass auch Packstücke mit neuen Varianten eines Gefahrgutlabels richtig erkannt werden. Hierzu wird ein Packstück zuerst von unterschiedlichen Seiten fotografiert. Auf jedem Foto werden mittels Bildvorverarbeitung und Segmentierungsalgorithmen Labels erkannt. Diese Fotos von Labels werden von Menschen klassifiziert (getaggt). Fotos der Labels und die entsprechenden Tags sind dann die Eingabe für ein Neuronales Netz, welches mit diesem Trainingsset trainiert wird (überwachtes Lernen). Nach der Trainingsphase kann das Neuronale Netz dann in einem Softwaretool angewandt werden, um in der späteren Anwendung ähnliche Labels automatisch zu identifizieren.

ERKENNUNG VON INDIVIDUELLEN WERKSTÜCKEN UND TRANSPORTHILFSMITTELN

Ein weiteres Beispiel für die Anwendung von ML-Verfahren für Erkennungsaufgaben in der Logistik ist die Identifizierung von einzelnen Werkstücken aufgrund optischer Merkmale. Beispielsweise kommen in der Stahlindustrie unterschiedlichste Werkstoffe (Stahllegierungen) zum Einsatz und die gefertigten Zwischenprodukte (Coils und Brammen) sehen auf den ersten Blick gleich aus. Derzeit existieren mehr als 2.500 Stahlsorten, welche sich in ihren mechanischen Eigenschaften (Härte und Verformbarkeit) und magnetischen Eigenschaften sowie hinsichtlich der Rost-,

Säure- und Hitzebeständigkeit unterscheiden. Die Erkennung des korrekten Werkstücks ist eine wichtige und nichttriviale Aufgabe. Die Stahlerzeugung ist jedoch dadurch charakterisiert, dass in vielen Fertigungsschritten Temperaturen von mehreren hundert Grad Celsius anfallen. Eine Kennzeichnung von Brammen, Coils oder Stangen mit Barcodes unmittelbar nach diesen Produktionsschritten ist nicht immer möglich. Jedoch können individuelle Stücke auf Basis optischer Eigenschaften erkannt werden: Die Wicklungsmuster von Coils ähneln Fingerabdrücken und einzelne Stangen können über ihre Sägemuster und ihre Geometrie erkannt werden. Auch hier können ML-Ansätze, insbesondere Neuronale Netze, zur Erkennung einzelner Werkstücke durch Fotos identifiziert werden.



Abbildung 11
Anhand der Oberfläche
eindeutig identifizierbare
Euro-Palette (Bild Fotolia)

Die gleichen Methoden können auch zur Erkennung individueller Transporthilfsmittel angewendet werden. So bilden beispielsweise die Maserungen der Holzbretter Holzblöcke im Fuß einer Palette eine Art Fingerabdruck, mit welcher einzelne Paletten erkannt werden können, ohne dass z. B. Seriennummern oder Label gelesen werden (vgl. Abbildung 11). Ähnlich wie beim Fingerabdruck reicht es aus, nur einen Teil der Oberfläche zu erkennen.

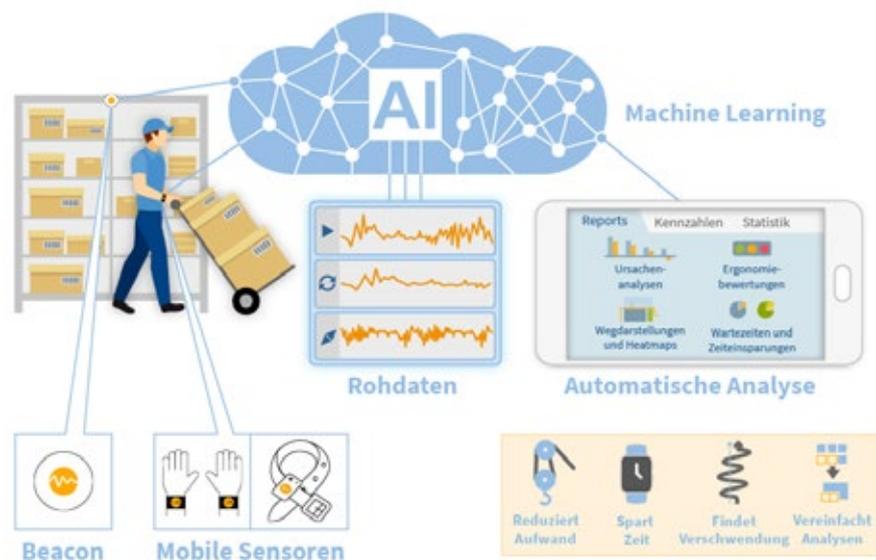
BEISPIELE FÜR ML FÜR ANALYSEAUFGABEN IN DER LOGISTIK

BEWEGUNGSANALYSE

Viele Aufgaben bei Transport, Umschlag und Lagerung werden von Menschen in physischer Arbeit ausgeführt. Für eine möglichst effiziente Ausführung einerseits und für die Erkennung möglicher physischer Belastungen der Mitarbeiter andererseits ist es notwendig, die durchgeführten Tätigkeiten – z. B. Heben oder Tragen von Packstücken – sowie die dafür aufgewendeten Zeiten zu kennen. Heutzutage werden diese Daten mit hohem manuellem Aufwand, z. B. über Multimomentaufnahmen und/oder der manuellen Auswertung von Videodaten erzeugt. Dabei werden Daten nur für einen kurzen Zeitraum erfasst. Somit ist die Stichprobe häufig nicht repräsentativ. Durch den Einsatz von Sensoren und Neuronalen Netzen kann diese Analyseaufgabe mit ML durchgeführt werden. Mitarbeiter tragen Sensoren,

die Daten aufnehmen. Mit ML-Verfahren werden in diesen Daten Muster erkannt, aus denen auf Aktivitäten geschlossen werden kann. Mit diesen Wearables und Motion-Capture-Verfahren zur Erfassung der Bewegungen der Mitarbeiter werden Daten über einen langen Zeitraum gesammelt. Diese Daten bilden die Eingabe für Neuronale Netze zur Klassifikation der Tätigkeiten anhand der erkannten Bewegungen. Das Neuronale Netz kann dann Muster erkennen, wie z. B. Bewegungsabläufe für Pickvorgänge – das Abholen von Ware aus einem Lagerfach. So kann ermittelt werden, wie viel Zeit für das Picken, für Wege im Lager oder für das Kommissionieren und Verpacken benötigt wird. Auch können gesundheitsschädliche Bewegungen wie beispielsweise unergonomisches Heben erkannt werden. Mit diesen durch KI aufbereiteten Rohdaten können dann Verbesserungen im Lager erfolgen (vgl. Abbildung 12).

Abbildung 12
Bewegungsklassifizierung
zur Analyse manueller
Tätigkeiten (Quelle: <https://www.motionminers.com/>)



PROGNOSE VON TRANSPORTANKUNFTSZEITEN

Das Ein-, Aus- und Umladen von Waren ist eine wichtige Aufgabe, die an vielen Logistikknoten, wie z. B. intermodale Terminals, Häfen, Flughäfen sowie den Wareneingangs- und Warenausgangsbereichen von Lagern und Umschlagpunkten durchzuführen ist. Für diese Tätigkeiten müssen Kapazitäten (freie Laderampenplätze, Stapler, Kräne und die jeweiligen Mitarbeiter) für die einzelnen Transporte eingeplant werden. Bei unzureichenden Kapazitäten kommt es zu Wartezeiten. Andererseits ist die Bereitstellung von Überkapazitäten mit erhöhten Betriebskosten verbunden. Betreiber von Logistikknoten sind daher daran interessiert, die Ankunftszeit von Transporten (LKW, Schiffe und Flugzeuge) im Voraus und so genau wie möglich zu kennen. In der Praxis ist dieser Kapazitätsbedarf oft stark schwankend und schwer

vorherzusagen, da vielfältige Faktoren den Bedarf beeinflussen können. Mit Ansätzen des Maschinellen Lernens können Daten aus verschiedenen Quellen (z. B. Transaktionsdaten von Logistikdienstleistern, Verkehrsdaten, Wetterdaten, Arbeitskalender) genutzt werden, um z. B. die Ankunftszeiten einzelner LKWs für die nächsten 48 Stunden vorherzusagen.

ABSATZPROGNOSE

ML-Verfahren, wie künstliche Neuronale Netze oder Entscheidungsbaum-basierte Methoden, können für Prognoseaufgaben in Supply Chains eingesetzt werden. Beispiele hierfür sind Bedarfsprognosen bezüglich Fertigerzeugnissen, Halbfertigprodukten und Teile bzw. Rohstoffen. Ebenso könnten auch Produktionskapazitätsbedarfe oder Transportbedarfe zwischen Supply-Chain-Standorten mit ML-Verfahren prognostiziert werden. Die entsprechenden ML-Ansätze können hierbei eine multivariate Prognose durchführen, die auf Transaktionsdaten aus der Lieferkette, z. B. historische Umsatztransaktionsdaten und öffentlich verfügbaren quantitativen Daten, z. B. Wirtschaftsdaten wie Wechselkurse sowie Daten aus dem Text Mining öffentlicher Quellen, z. B. Online-Zeitungen und Zeitschriften oder Unternehmenswebsites, basiert. Das heißt, aus mehreren Zeitreihen wird der zukünftige Bedarf mit ML-Verfahren des bestärkenden Lernens prognostiziert.

BEISPIELE FÜR ML FÜR PLANUNGS- UND ENTSCHEIDUNGSAUFGABEN IN DER LOGISTIK

Unternehmen setzen für die Verwaltung und Steuerung ihrer Prozesse häufig IT-Systeme, wie bspw. Enterprise Resource Planning (ERP)-, Manufacturing Execution (MES) und/oder Warehouse Management (WMS)- Systeme, ein, mit welchen z. B. Fertigungsaufträge generiert und bearbeitet werden können. Diese Systeme erfordern Eingaben von Mitarbeitern über den Zustand der Aufträge (z. B. Fertigmeldungen), der Maschinen (z. B. Störmeldungen) und der Mitarbeiter selbst (Informationen über Pausenzeiten). Diese Kommunikation erfolgt heute oft durch Papierausdruck, Anzeigen und Bedienelemente an den entsprechenden Maschinen.

PERSONALISIERTE PAUSENEMPFEHLUNG

Motivation für diese Anwendung ist die Tatsache, dass ermüdete Mitarbeiter verstärkt Fehler bei der Bedienung von Fertigungsanlagen sowie bei der Zusammenstellung von Kundenaufträgen in der Kommissionierung machen. Im schlimmsten Fall können hierbei sogar Mitarbeiter verletzt werden. Auch können durch Fehlbedienungen mangelhafte Produkte hergestellt und/oder die Anlagentechnik beschädigt werden. Durch eine automatische Stresserkennung werden die

Arbeitsbedingungen der Mitarbeiter verbessert, indem die betroffenen Mitarbeiter rechtzeitig „in die Pause geschickt werden“. Solche Systeme zur Ermüdungserkennung beim Autofahren sind bereits seit einiger Zeit auf dem Markt. Für Aufgaben in der Logistik können hier Wearables zum Einsatz kommen, welche z. B. Pulsdaten permanent aufnehmen, um physischen und mentalen Stress zu bestimmen. Mit einem künstlichen Neuronalen Netzwerk können dann z. B. Empfehlungen für Pausen bestimmt werden, die auf visuellen Eingabedaten (Bewegungsdaten), Vitaldaten und Daten für den Betrieb von Maschinen (z. B. Reaktionszeit) basieren.

LADUNGSBILDUNG

Bei der Ladungsbildung werden unterschiedliche Packstücke in einer Sendung kombiniert, um diese dann mit einem entsprechenden Ladungsträger zu verschicken. Beispielsweise können mehrere Handelsartikel in Primärverpackungen in unterschiedlichen Dimensionen auf einer EURO-Palette verpackt werden. Für den Transport ist es aus Kostengründen und zur Vermeidung von Transportschäden wichtig, dass hierbei die Palette möglichst eng gepackt ist und möglichst keine Packstücke überstehen. Denn schlecht kombinierte Ladungen führen zu einem niedrigeren Füllgrad der LKW und können die Ladungssicherheit gefährden. Mit Convolutional Neural Networks (CNN) können diese Planungsaufgaben automatisiert werden: Bei diesen CNN besteht das Netz aus vielen unterschiedlichen „gestapelten“ Schichten. Die unterste Ebene dient dabei zur Eingabe eines Fotos eines Ladungsträgers. Auf dieser Eingabeschicht werden dann mehrere Schichten (Convolutional Layers) „gestapelt“. Neuronen eines Convolutional Layers sind nur mit einem rechteckigen Unterbereich der vorherigen Schicht verknüpft. Mittels eines überwachten Lernens wird das Netz mit klassifizierten (korrekt versus unkorrekte Ladungsträger) Fotos von Ladungsträgern trainiert. Damit kann das CNN lernen, ob es z. B. auf einer Palette überstehende Kartons gibt.

TRANSPORTMITTELAUSWAHL

Die Arbeit der Disponenten in globalisierten und hochdigitalisierten Supply Chains wird durch moderne Track-and-Trace-Lösungen stark beeinflusst. Diese Systeme tragen wesentlich dazu bei, Abweichungen von den gewünschten Auftragszuständen – Verspätungen/Ausfall von Transporten, Sperrung von Straßen etc. – zu erkennen. Entsprechende Systeme werden auch als Supply-Chain-Event-Management-Systeme bezeichnet. Für einen möglichst reibungslosen Transport in Supply Chains ist es jedoch nicht ausreichend nur zu wissen, dass eine Störung aufgetreten ist. Vielmehr müssen geeignete Gegenmaßnahmen – z. B. Einsatz von Zusatztransporten, Wahl anderer Transportrouten und/oder Transportmodi oder verlängerte

Öffnungszeiten für die Warenannahme – ergriffen werden. Dabei ist zu beachten, dass die Zeit für die Identifikation und Bewertung von Gegenmaßnahmen und sub-sequenten Auswahl der besten Lösungen meist sehr kurz ist. In der Praxis wird oft die „Erst-beste-Lösung“ gewählt. Die Auswahl geeigneter Maßnahmen (Sondertransporte, Anpassung von Abfahrten im Nachlauf) zur Lösung der so festgestellten Probleme kann durch die Anwendung von ML verbessert werden. ML-Systeme können im operativen Einsatz den Erfolg und/oder Misserfolg von einzelnen Maßnahmen überwachen und sukzessive bessere Lösungen lernen.

BEISPIELE FÜR ML FÜR AUSFÜHRUNGS-AUFGABEN IN DER LOGISTIK

MENSCH-MASCHINE-INTERAKTION

Für die Durchführung von logistischen Aufgaben kommunizieren Maschinen mit Menschen über natürliche Sprache, z. B. beim Einsatz von Pick-by-Voice-Systemen in der Kommissionierung. Durch den Einsatz von ML in der Sprachsteuerung können diese Aufgaben effizienter und sicherer durchgeführt werden. Für diese Sprachsteuerung ist es erforderlich, dass die von den Menschen erteilten Kommandos durch die Systeme richtig und schnell erkannt werden. Mit ML-Ansätzen – insbesondere künstlichen Neuronalen Netzen – können sogenannte Sprachbots trainiert werden, welche die Besonderheiten hinsichtlich der Aussprache der einzelnen Sprecher lernen. Entsprechende Systeme, wie z. B. Alexa, Siri, Cortana und Co. sind seit einiger Zeit im B2C-Bereich im Einsatz.

STEUERUNG VON AUTONOMEN FAHRZEUGSCHWÄRMEN

Für den innerbetrieblichen Transport werden seit langem frei fahrbare Fahrzeuge wie z. B. Stapler oder Handhubwagen eingesetzt. Diese Fahrzeuge werden durch Menschen gesteuert, um Kollisionen eines Fahrzeugs mit Menschen, anderen Fahrzeugen oder der Werks- und Lagerinfrastruktur zu vermeiden. Eine Automatisierung des innerbetrieblichen Transports wurde bisher immer mit einer „starrten“ Logistik durch den Einsatz von Schienensystemen und/oder einer klaren Trennung von Mitarbeitern und Fördertechnik „erkaufte“. Mit ML strebt man an, die Flexibilität der menschlichen Steuerung mit automatisierten Transportmitteln zu erreichen. Bei der Navigation von Fahrzeugschwärmen gilt es dabei das Problem zu lösen, mehrere autonome Roboter in einem System so zu koordinieren, dass sie untereinander oder mit anderen Objekten nicht kollidieren und gleichzeitig ihre Transportaufträge durchführen. Für diesen Anwendungsfall wurde am Fraunhofer IML zusammen mit der TU Dortmund der Transportroboter Loadrunner® entwickelt [21]. Basierend auf dem wahrgenommenen Systemzustand treffen die Fahrzeuge eigene Entscheidungen und können flexibel auf Änderungen ihrer Umgebung

reagieren. Hierbei soll der Transportroboter seine Position und seine Bewegungsrichtung über ein ML-Modell bestimmen, welches auf Basis von optischen Mustern im Bodenbelag trainiert worden ist. Mit diesen Informationen „weiß“ ein einzelner Loadrunner® wo er sich genau befindet und kann sich so zur Kollisionsvermeidung mit den anderen Loadrunner® abstimmen (vgl. Abbildung 13).

Abbildung 13
Loadrunner®
übernimmt Packstücke



Projekte mit Maschinellem Lernen – Wie starten?

Beim Einstieg in die Thematik kommt es häufig zu vermeidbaren Fehlern, was bereits früh zum Scheitern von ML-Projekten führt. Die Erfahrungen am Fraunhofer IML haben gezeigt, dass vor allem folgende Punkte bei ML-Projekten zu beachten sind:

1. Es gilt darauf zu achten, zuerst die Problemstellung zu identifizieren und zu überprüfen, mit welchen Verfahren diese gelöst werden kann. Dabei ist es empfehlenswert, zuerst kleine Anwendungsfälle anzugehen, denn dabei können am besten die Vorteile und auch Grenzen von ML kennengelernt werden. Eine Erweiterung auf größere Anwendungsfälle ist auf Basis einer Teillösung einfacher umzusetzen als direkt eine allumfassende Lösung zu entwickeln.

2. Um die Entscheidung für eine ML-basierte Lösung zu erleichtern, sollten vorher einige Fragen beantwortet werden. So zum Beispiel, ob genügend Ressourcen im Unternehmen vorhanden sind, um das Projekt alleine zu stemmen. Die Mehrzahl der Unternehmen, die bereits Projekte begonnen haben oder Anwendungen im Bereich des ML operativ einsetzen, führten diese nicht im Alleingang durch, sondern gemeinsam mit einem externen Partner (vgl. [21]). Dabei wurden vor allem IT-Dienstleister, Universitäten und Forschungseinrichtungen sowie Unternehmensberater genutzt. Die Kombination aus fachspezifischem Wissen der Unternehmen gepaart mit dem entsprechenden IT-Know-how stellte sich dabei als besonderes erfolgreich heraus.
3. Eine weitere entscheidende Frage zu Beginn des Projektes ist, auf welcher Grundlage die Lösungen aus dem Bereich des ML agieren sollen. Wie bereits ausgeführt sind hierbei neben den Hardwarevoraussetzungen die Daten, auf denen gelernt werden soll, ein entscheidender Eckpfeiler eines erfolgreichen Projekts. Hierbei muss überprüft werden, welche Daten bereits vorhanden sind oder ob zu Beginn des Projektes erst einmal Daten gesammelt werden müssen, die eine Lernumgebung ermöglichen. Die Anzahl und die Qualität der benötigten Daten sind dabei in Abhängigkeit des Anwendungsfalls und der angestrebten Lösung zu sehen. Hierfür gibt es keine allgemeine Formel oder Regel, die dies vorgibt. Jedoch sind oftmals viele Daten in einer hohen Qualität das zu erstrebende Ziel.
4. Für den Einstieg in das Thema Hardware und Softwarevoraussetzungen gibt es mehrere Wege, die sich als erfolgreich herausgestellt haben. Für viele Unternehmen findet der technische Einstieg in das Thema beispielsweise als „Machine Learning as a Service“ über cloudbasierte externe Lösungen statt. Weiterhin werden in produktiven Einsatzszenarien auch die Möglichkeit des externen Hostings sowie der Betrieb von vorhandenen Frameworks in der Cloud genutzt.

Schlussbetrachtung

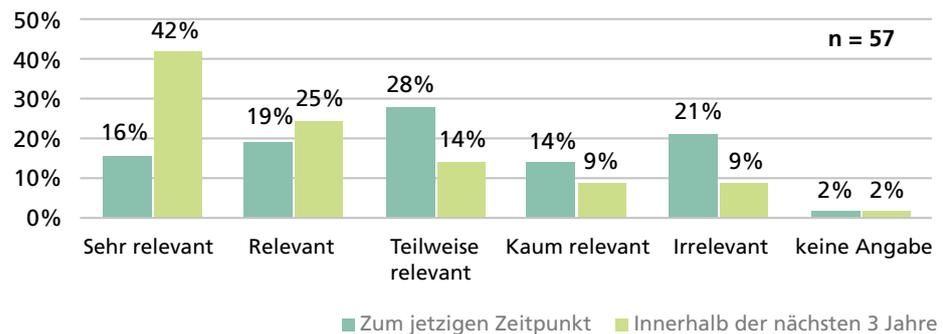
QUALIFIZIERUNGSBEDARFE

Der Einsatz von ML-Methoden wird stark durch die Entwicklung der IT-Infrastruktur gefördert. Mit neue Kommunikationstechnologien, wie 5G-Netze, können durch I4.0-Technologien generierte Daten schnell und von überall in Cloudsysteme übertragen werden. Dort können große Rechenleistungen für das Training von auf den

Daten basierenden ML-Modellen genutzt werden und die Erkenntnisse entweder zurück zu den Technologien geschickt oder für weiterführende Auswertungen genutzt werden.

Die hiermit einhergehende Einschätzung der aktuellen und zukünftigen Relevanz von KI wird durch viele Unternehmen geteilt (vgl. Abbildung 14).

Abbildung 14
Einschätzung der Bedeutung von ML für Unternehmen ([21])



Andererseits sind KI-Systeme in der Logistik noch nicht sehr verbreitet. Hieraus ergibt sich erheblicher Informations- und Qualifizierungsbedarf bezüglich KI und ML für die Unternehmen (vgl. [1] und [22]). Der Stellenwert entsprechender Transferaktionen wurde auch von Bund und Ländern erkannt und es entstehen öffentlich geförderte Angebote wie die KI-Trainer im Mittelstand 4.0 Kompetenzzentrum [23] und der Research Clan Maschinelles Lernen im Leistungszentrum Logistik und IT [24].

KI IN DER LOGISTIK: CHANCEN UND AUSBLICK

So vielfältig wie die Aufgaben der Logistik sind, so vielfältig sind die Einsatzmöglichkeiten von KI in der Logistik. Die Chancen zum effizienteren Ressourceneinsatz, zur Verbesserung der logistischen Leistungen und die Ermöglichung neuer Geschäftsmodelle durch KI in der Logistik sind erheblich. Es gilt, dieses Potenzial insbesondere mit agilen Vorgehensweisen verstärkt in die Praxis zu bringen.

Literaturverzeichnis

- [1] BMBF (2018): Eckpunkte der Bundesregierung für eine Strategie Künstliche Intelligenz. URL: https://www.bmbf.de/files/180718%20Eckpunkte_KI-Strategie%20final%20Layout.pdf – abgerufen am 12.02.2021.
- [2] Rohleder, B.: Digitalisierung der Logistik (2019). https://www.bitkom.org/sites/default/files/2019-06/bitkom-charts_digitalisierung_der_logistik_03_06_2019.pdf – abgerufen am 22.02.2021.
- [3] Tata Consultancy Service Limited (2020). Deutschland lernt KI: Wie Unternehmen digitale Technologien einsetzen - <https://www.tcs.com/de-de/trendstudie-digitalisierung/studie-digitalisierung-2020> abgerufen am 09.03.2021
- [5] ten Hompel, M.: Das Big Picture der Silicon Economy; in: LTManager – Das Premiummagazin für Logistik und Transport, Nr. 46-01/2019, S. 10-15.
- [5] Hvolby, H.; Steger-Jensen, K.: Technical and industrial issues of Advanced Planning and Scheduling (APS) systems. In: Computers in Industry, Volume 61, Issue 9, 2010, S. 845-851.
- [6] BVL (2020): Logistikumsatz und Beschäftigung – Bedeutung der Logistik für die deutsche Wirtschaft. URL: <https://www.bvl.de/service/zahlen-daten-fakten/umsatz-und-beschaeftigung> – abgerufen am 12.02.2021.
- [7] The World Bank (2018): International LPI (Logistic Performance Index). URL: <https://lpi.worldbank.org/international/global> – abgerufen am 12.02.2021.
- [8] Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2018). Notes from the Frontier – Modeling the Impact of AI on the Global Economy. McKinsey Global Institute.
- [9] Turing, A. M. (1950). Computing machinery and intelligence. Mind – a Quarterly Review of Psychology and Philosophy, 59(236), 433-460.
- [10] Frochte, J. (2020). Maschinelles Lernen: Grundlagen und Algorithmen in Python. Carl Hanser Verlag GmbH Co KG.
- [11] Fraunhofer-Allianz Big Data & Künstliche Intelligenz (2018). Maschinelles Lernen: Eine Analyse zu Kompetenzen, Forschung und Anwendung. https://www.bigdata.fraunhofer.de/content/dam/bigdata/de/documents/Publikationen/Fraunhofer_Studie_ML_201809.pdf – abgerufen am 12.02.2021 von
- [12] Hill, K.: How Target Figured Out A Teen Girl Was Pregnant Before Her Father Did. <https://www.forbes.com/sites/kashmirhill/2012/02/16/how-target-figured-out-a-teen-girl-was-pregnant-before-her-father-did/#788589776668> – abgerufen am 12.02.2021
- [13] Beuth, P. Schwanger ohne digitale Spuren. <https://www.zeit.de/digital/datenschutz/2014-04/big-data-schwangerschaft-verheimlichen> – abgerufen am 12.02.2021
- [14] Silver, D. et al. (2018). A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play. Science (New York, N.Y.), 362(6419), 1140–1144. <https://doi.org/10.1126/science.aar6404>
- [15] Silver, D.; Hassabis, D (2017): AlphaGo Zero: Starting from scratch. <https://deepmind.com/blog/article/alphago-zero-starting-scratch> – abgerufen am 12.02.2021.
- [16] Deisenroth, M. P., Faisal, A. A., & Ong, C. S. (2020). Mathematics for machine learning: Cambridge university press.

- [17] INFORM (2018): Künstliche Intelligenz – Zukunftsträger der Logistik? URL: <https://www.inform-software.de/news/news-details/news/kuenstliche-intelligenz-zukunftstraeger-der-logistik> – abgerufen am 12.02.2021.
- [18] Wolf, O., Nettsträter, A., Ebel, D., Geißen, T., Kraft, V., Mertens, C., Pott, C., Schoneboom, J., Witthaut, M. & Hompel, M. ten (Hrsg.) (2013). IT in der Logistik 2013/2014: Marktübersicht & Funktionsumfang: Enterprise-Ressource. –Planning, Warehouse-Management, Transport-Management & Supply-Chain-Management-Systeme. Stuttgart: Fraunhofer Verlag
- [19] Hänsel, F., Baumgärtner, S. D., Kornmann, J. M., & Ennigkeit, F. (2016). Kognition. In F. Hänsel, S. D. Baumgärtner, J. M. Kornmann, & F. Ennigkeit (Eds.): Sportpsychologie. Berlin: Springer.
- [20] Blutner, D., Cramer, S., Krause, S., Mönks, T., Nagel, L., Reinholz, A., & Witthaut, M. (2009). Assistenzsysteme für die Entscheidungsunterstützung. In P. Buchholz & U. Clausen (Eds.), Große Netze der Logistik: Die Ergebnisse des Sonderforschungsbereichs 559 (pp. 241–270). Berlin: Springer.
- [21] ten Hompel, M., Bayhan, H., Behling, J., Benkenstein, L., Emmerich, J., Follert, G., & Hoppe, C. (2020). Technical Report: LoadRunner®, a new platform approach on collaborative logistics services. Logistics Journal: nicht referierte Veröffentlichungen, 2020(10).
- [22] Culotta, C.; Witthaut, M. (2020). Einsatz von Machine Learning in der Logistik. Logistics Journal: nicht referierte Veröffentlichungen, 2021(05).
- [23] Digital in NRW (2019): Künstliche Intelligenz für Unternehmen. <https://www.digital-in-nrw.de/de/schritt-fuer-schritt/ki-trainer> – abgerufen am 12.02.2021.
- [24] Leistungszentrum Logistik und IT (2019): Maschinelles Lernen: Neuer Research-Clan schreibt Forschungsagenda. <https://leistungszentrum-logistik-it.de/maschinelles-lernen-neuer-research-clan-schreibt-forschungsagenda/> – abgerufen am 12.02.2021.

